

Feature classification using supervised statistical pattern recognition.

Patent Number: EP0572335, A3

Publication date: 1993-12-01

Inventor(s): HERBERT THOMAS FRANCIS C O EAS (US)

Applicant(s): EASTMAN KODAK CO (US)

Requested Patent: JP6036038

Application Number: EP19930420207 19930525

Priority Number(s): US19920890401 19920529

IPC Classification: G06K9/62

EC Classification: G06K9/68A1, G06K9/62B8

Equivalents: CA2094212, US5325445

Cited patent(s):

Abstract

Feature classification using a novel supervised statistical pattern recognition approach is described. A tree-like hierarchical decomposition of n-dimensional feature space is created off-line from an image processing system (80). The hierarchical tree is created through a minimax-type decompositional segregation of n-dimensional feature vectors of different feature classifications within the corresponding feature space. Each cell preferably contains feature vectors of only one feature classification, or is empty, or is of a predefined minimum cell size. Once created, the hierarchical tree is made available to the image processing system (80) for real-time defect classification of features in a static or moving pattern. Each feature is indexed to the classification tree by locating its corresponding feature vector in the appropriate feature space cell as determined by a depth-first search of the hierarchical tree. The smallest leaf node which includes that feature vector provides the statistical information on the vector's classification.



Data supplied from the **esp@cenet** database - I2

(19) 日本国特許庁 (JP)

(12) 公開特許公報 (A)

(11) 特許出願公開番号

特開平6-36038

(43) 公開日 平成6年(1994)2月10日

(51) Int.C1.⁵
G06F 15/70識別記号 庁内整理番号
465 Z 8837-5L

F I

技術表示箇所

審査請求 未請求 請求項の数34 (全33頁)

(21) 出願番号 特願平5-126688

(22) 出願日 平成5年(1993)5月28日

(31) 優先権主張番号 890, 401

(32) 優先日 1992年5月29日

(33) 優先権主張国 米国(US)

(71) 出願人 591264544

イーストマン・コダツク・カンパニー
アメリカ合衆国、ニュー・ヨーク・14650
、ロチエスター、ステイト・ストリート・
343

(72) 発明者 トマス フランシス ハーバート

アメリカ合衆国 ニューヨーク州 ロチエ
スター ノース ランディング ロード
794

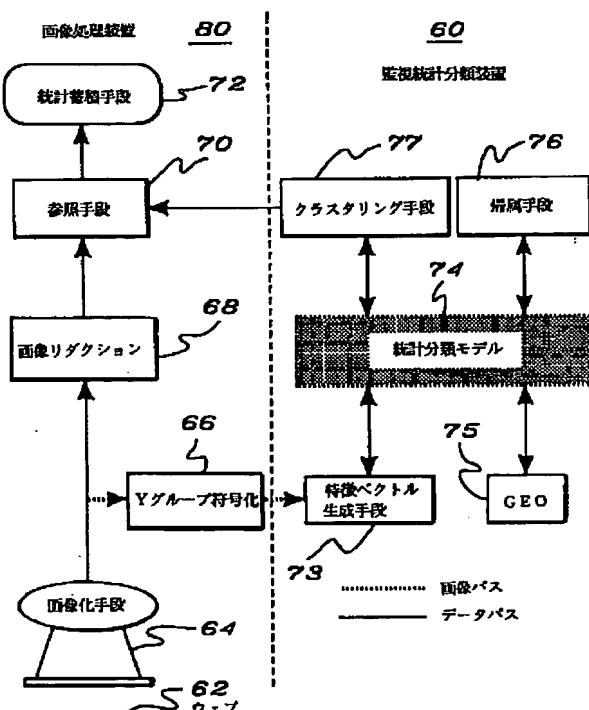
(74) 代理人 弁理士 吉田 研二 (外2名)

(54) 【発明の名称】監視統計パターン認識を用いる特徴分類

(57) 【要約】

【目的】 監視統計パターン認識法により、画像不良の特徴分類を行う。

【構成】 画像処理システム80により、n次元特徴空間のツリー状階層分解がオフラインで生成される。階層ツリーは、異なる特徴分類のn次元特徴分類をミニマクスタイプの分解によって分割することにより、対応する特徴空間内に生成される。各セルは、好適には、ただ1つの特徴分類の特徴ベクトルを含むか、空であるか、定義済みの最少セルサイズである。生成された階層ツリーは、画像処理システム80が、静止パターンまたは動画パターンにおける特徴の不良分類を実時間で実施するのに利用することができる。各特徴は、深さを優先した階層ツリーの探索によって決められたように、対応する特徴ベクトルを適切な特徴空間セルに配置することにより、分類ツリーに索引付けされる。その特徴ベクトルを含む最少リーフノードは、そのベクトルの分類に関する統計情報を提供する。



【特許請求の範囲】

【請求項 1】 複数の特徴を有するサンプルテスト画像から統計分類モデルを生成する方法において、前記統計分類モデルが、画像処理システム(80)によって実時間特徴分類に使用され、

前記統計分類モデルを生成する方法が、

(a) 前記複数の特徴を有する前記サンプルテストを画像化し、それらのデジタル画像表現を生成するステップと、

(b) 前記デジタル画像表現を参照することにより、独自の分類を前記サンプルテスト画像中の同一タイプの選択された特徴に帰属するステップと、

(c) 前記ステップ(b)で分類された各特徴に対してn個の要素から成る特徴ベクトルを生成するステップと、

(d) 前記ステップ(b)で帰属された前記分類を使用して特徴ベクトルを特徴空間においてクラスタリングするステップと、

(e) 新規画像を実時間で特徴分類するための前記画像処理システム(80)によるアクセスに備え、ステップ

(d) の前記クラスタリングの結果生成した階層的に分解されたn次元特徴空間を記憶するステップと、を含み、

前記ステップ(c)の前記n個の要素から成る特徴ベクトルが対応するn次元特徴空間を定義し、前記ステップ(d)の前記クラスタリングがミニマクスサーチを用い、前記帰属された特徴分類に基づいてn次元特徴空間のツリー状階層分解を定義することを特徴とする統計分類モデルを生成する方法。

【請求項 2】 請求項1記載の統計分類モデルを生成する方法において、

前記ミニマクスサーチクラスタリングステップ(d)が、各最終特徴セルが同一分類に対応する特徴ベクトルのみを含むか、空であるか、前記分解特徴空間に対する定義済みの最小セルサイズであるよう、n次元特徴空間の階層分解を定義することによって実施されることを特徴とする統計分類モデルを生成する方法。

【請求項 3】 請求項2記載の統計分類モデルを生成する方法において、

前記サンプルテスト画像中に少なくとも2つの異なる特徴タイプが存在し、前記ステップ(b)が独自の分類を前記特徴タイプのそれぞれに帰属するステップを含むことを特徴とする統計分類モデルを生成する方法。

【請求項 4】 請求項3記載の統計分類モデルを生成する方法において、

各特徴タイプの複数の特徴が階層的に分解されたn次元特徴空間内にクラスタリングされるよう、複数のサンプルテスト画像に対して、ステップ(a)から(d)を累積的に反復するステップを含むことを特徴とする統計分類モデルを生成する方法。

【請求項 5】 請求項3記載の統計分類モデルを生成する方法において、

前記クラスタリングステップ(d)が、

(i) 特徴ベクトルを選択し、前記特徴ベクトルを特徴空間内に配置するステップと、

(ii) 別の特徴ベクトルを選択し、前記別の特徴ベクトルを前記特徴空間内に配置するステップと、

(iii) 少なくとも2つの異なる分類の特徴ベクトルが同一の特徴空間セル内に配置されている場合に前記特徴空間を選択的に分解し、前記少なくとも2つの異なる分類の特徴ベクトルが異なるセルに配置されるか、前記定義済みの最小セルサイズに達するまで前記選択的分解が継続するステップと、

(iv) ステップ(c)で生成された前記特徴ベクトルのそれぞれに対してステップ(ii)及び(iii)を反復するステップと、を含み、

前記ステップ(iv)において、生成したステップ(ii)の分解特徴空間が、n次元特徴空間のツリー状階層分解であることを特徴とする統計分類モデルを生成する方法。

【請求項 6】 請求項3記載の統計分類モデルを生成する方法において、

前記ステップ(c)が、前記ステップ(d)が多次元特徴空間のツリー状階層分解を生成するよう、デジタル表現の画像における各分類特徴に対して多要素特徴ベクトルを生成するステップを含むことを特徴とする統計分類モデルを生成する方法。

【請求項 7】 請求項3記載の統計分類モデルを生成する方法において、

前記ステップ(d)で用いられる前記ミニマクスサーチが、特徴空間を2のべき乗によって選択的に分解するステップを含むことを特徴とする統計分類モデルを生成する方法。

【請求項 8】 請求項7記載の統計分類モデルを生成する方法において、

前記ステップ(d)の前記ミニマクスサーチに対する特徴空間の最大レベルを設定するステップを含むことを特徴とする統計分類モデルを生成する方法。

【請求項 9】 請求項8記載の統計分類モデルを生成する方法において、

前記ステップ(d)の間に、前記特徴空間の前記ミニマクスサーチ分解に対する最小セルサイズを決定するステップを含むことを特徴とする統計分類モデルを生成する方法。

【請求項 10】 請求項3記載の統計分類モデルを生成する方法において、

n次元特徴空間の前記ツリー状階層分解を前記オンライン画像処理システムに転送するステップを含むことを特徴とする統計分類モデルを生成する方法。

50 【請求項 11】 請求項3記載の統計分類モデルを生成

する方法において、

前記分類帰属ステップ (b) が、オペレータによって手動で実施されることを特徴とする統計分類モデルを生成する方法。

【請求項 12】 請求項 3 記載の統計分類モデルを生成する方法において、

前記画像化ステップ (a) が、特徴を画像化サンプルテスト画像内の結合した領域として定義し、前記結合した領域の n 個の幾何学的測定値を取得するステップを含み、

前記幾何学的測定値が、前記ステップ (c) で前記 n 個の要素から成る特徴ベクトルを形成するのに用いられるこことを特徴とする統計分類モデルを生成する方法。

【請求項 13】 請求項 4 記載の統計分類モデルを生成する方法において、

生成した n 次元特徴空間の階層分解が、前記画像処理システム (80) による新規画像の実時間特徴分類用の監視分類装置を含むことを特徴とする統計分類モデルを生成する方法。

【請求項 14】 監視統計分類装置を使用してウェブの特徴を分類する実時間画像処理方法において、

前記統計分類装置が、異なる特徴タイプが階層ツリーの異なる特徴空間セルでクラスタリングされる n 次元特徴空間のツリー状階層分解を含み、
前記実時間画像処理方法が、

(a) 前記ウェブ (62) を画像化し、そのデジタル画像表現を生成するステップと、

(b) 前記監視統計分類装置を参照し、特徴ベクトルを、n 次元特徴空間の前記ツリー状階層分解の対応する特徴空間セル内に自動的に配置するステップと、

(c) 前記ステップ (b) の前記配置特徴ベクトルに基づいて画像化特徴に関する統計を蓄積するステップと、を含み、

前記ステップ (a) の前記画像化が、選択されたウェブの特徴に対する n 次元特徴ベクトルを生成するステップを含み、

前記ステップ (b) において、前記特徴ベクトルのそれぞれに対し、前記配置ステップが、前記特徴ベクトルを含む前記階層ツリーの最小セルに対して特徴空間の前記階層分解を探索するステップを含み、

前記ステップ (c) の前記統計が、各配置された特徴ベクトルに対し、前記対応する特徴に対する特徴タイプ分類を供与することを特徴とする実時間画像処理方法。

【請求項 15】 請求項 14 記載の実時間画像処理方法において、

前記監視統計分類装置が、多次元特徴空間のツリー状階層分解を含み、前記画像化ステップ (a) が、選択されたウェブの特徴に対して多次元特徴ベクトルを生成するステップを含むことを特徴とする実時間画像処理方法。

【請求項 16】 請求項 14 記載の実時間画像処理方法

において、

前記ステップ (a) において画像化される前記ウェブ (62) が可動であることを特徴とする実時間画像処理方法。

【請求項 17】 請求項 16 記載の実時間画像処理方法において、

前記可動ウェブがフィルム材の可動ウェブから成り、前記ステップ (a) で画像化される前記ウェブの特徴が、前記フィルム材上の欠陥を含むことを特徴とする実時間

10 画像処理方法。

【請求項 18】 請求項 16 記載の実時間画像処理方法において、

前記可動ウェブが可動ウェブ材から成り、前記ステップ (a) で画像化される前記ウェブの特徴が、前記可動ウェブ材上の表面欠陥を含むことを特徴とする実時間画像処理方法。

【請求項 19】 請求項 14 記載の実時間画像処理方法において、

前記ステップ (a) から (c) 以前に前記監視統計分類装置をあらかじめ定義するステップを含むことを特徴とする実時間画像処理方法。

【請求項 20】 請求項 19 記載の実時間画像処理方法において、

前記ステップ (b) 中に実時間で参照するための前記監視統計分類装置をあらかじめ記憶するステップを含むことを特徴とする実時間画像処理方法。

【請求項 21】 請求項 19 記載の実時間画像処理方法において、

前記分類装置をあらかじめ定義するステップが、
30 (i) 特徴を有する複数のサンプルテスト画像を画像化し、それらのデジタル画像表現を生成するステップと、

(ii) 前記デジタル画像表現を参照することにより、独自の分類を同一タイプの選択された特徴に帰属するステップと、

(iii) 前記ステップ (ii) で分類された各特徴に対して n 個の要素から成る特徴ベクトルを生成するステップと、

(iv) 前記ステップ (ii) で帰属された前記分類を 40 使用して特徴ベクトルを特徴空間においてクラスタリングするステップと、を含み、

前記ステップ (iii) の前記 n 個の要素から成る特徴ベクトルが対応する n 次元特徴空間を定義し、
前記ステップ (iv) の前記クラスタリングがミニマクスサーチを用い、前記帰属された特徴分類に基づいて n 次元特徴空間のツリー状階層分解を定義し、n 次元特徴空間の前記ツリー状階層分解が、前記監視統計分類装置を含むことを特徴とする実時間画像処理方法。

【請求項 22】 請求項 21 記載の実時間画像処理方法において、

50

前記ステップ (i v) で用いられる前記ミニマクスサーチが、特徴空間を 2 のべき乗によって選択的に分解するステップを含むことを特徴とする実時間画像処理方法。

【請求項 23】 請求項 14 記載の実時間画像処理方法において、

前記ステップ (c) で蓄積された前記統計を、前記画像化ウェブの品質管理用に、印字か、表示か、あるいは、前記統計を処理装置にダウンロードすることによって転送するステップを含むことを特徴とする実時間画像処理方法。

【請求項 24】 監視統計分類装置 (60) を使用してウェブ (62) の特徴を分類する実時間画像処理装置 (80) において、

前記統計分類装置が、異なる特徴タイプが階層ツリーの異なる特徴空間セルにクラスタリングされる n 次元特徴空間のツリー状階層分解を含み、

前記実時間画像処理装置が、

前記ウェブを画像化し、そのデジタル画像表現を生成する画像化手段 (64) と、

前記監視統計分類装置 (60) を参照し、特徴ベクトルを、n 次元特徴空間の前記ツリー状階層分解の対応する特徴空間セル内に自動的に配置する参照手段 (70) と、

前記配置特徴ベクトルに基づいて前記選択されたウェブの特徴に関する統計を蓄積する統計蓄積手段 (72) と、を含み、

前記画像化手段 (64) が、選択されたウェブの特徴に対する n 次元特徴ベクトルを生成する手段を含み、前記参照手段 (70) において、前記特徴ベクトルのそれぞれに対し、前記配置手段が、前記特徴ベクトルを含む前記階層ツリーの最小セルに対して特徴空間の前記階層分解を探索する手段から成り、前記統計蓄積手段 (72) の前記統計が、各配置された特徴ベクトルに対し、前記対応するウェブの特徴に対する特徴タイプ分類を供与することを特徴とする実時間画像処理装置。

【請求項 25】 請求項 24 記載の実時間画像処理装置において、

前記監視統計分類装置 (60) が前記参照手段 (70) によって実時間探索を実行できるように維持するための記憶手段を含むことを特徴とする実時間画像処理装置。

【請求項 26】 請求項 24 記載の実時間画像処理装置において、

前記画像手段によって画像化される前記ウェブ (62) が可動であることを特徴とする実時間画像処理装置。

【請求項 27】 請求項 26 記載の実時間画像処理装置において、

前記ウェブがフィルム材の可動ウェブから成り、前記画像手段によって画像化される前記ウェブの特徴が、前記フィルム材上の欠陥を含むことを特徴とする実時間画像

処理装置。

【請求項 28】 請求項 26 記載の実時間画像処理装置において、

前記ウェブが可動ウェブ材から成り、前記画像手段によって画像化される前記ウェブの特徴が、前記可動ウェブ材上の表面欠陥を含むことを特徴とする実時間画像処理装置。

【請求項 29】 請求項 24 記載の実時間画像処理装置において、

10 前記監視統計分類装置をあらかじめ定義する手段を含み、

前記あらかじめ定義する手段が、

特徴を有する複数のサンプルテスト画像を画像化し、それらのデジタル画像表現を生成する画像化手段 (64) と、

前記デジタル画像表現を参照することにより、独自の分類を同一タイプの選択された特徴に帰属する帰属手段 (76) と、

分類された各特徴に対して n 個の要素から成る特徴ベクトルを生成する特徴ベクトル生成手段 (73) と、

前記帰属された分類を使用して特徴ベクトルを特徴空間においてクラスタリングするクラスタリング手段 (77) と、を含み、

前記特徴ベクトル生成手段 (73) によって生成される前記 n 個の要素から成る特徴ベクトルが対応する n 次元特徴空間を定義し、

前記クラスタリング手段 (77) がミニマクスサーチを用い、前記帰属された特徴分類に基づいて n 次元特徴空間のツリー状階層分解を定義し、n 次元特徴空間の前記ツリー状階層分解が、前記監視統計分類装置を含むことを特徴とする実時間画像処理装置。

【請求項 30】 請求項 29 記載の実時間画像処理装置において、

前記クラスタリング手段 (77) で用いられる前記ミニマクスサーチが、特徴空間を 2 のべき乗によって選択的に分解する手段を含むことを特徴とする実時間画像処理装置。

【請求項 31】 複数の特徴を有するサンプルテスト画像から統計分類モデル (74) を生成する装置において、

前記統計分類モデルが画像処理システムによって実時間特徴分類に使用され、

前記モデル生成装置が、

前記サンプルテスト画像を画像化し、それらのデジタル画像表現を生成する画像化手段 (64) と、

前記デジタル画像表現を参照することにより、独自の分類を同一タイプの選択された特徴に帰属する帰属手段 (76) と、

分類された各特徴に対して n 個の要素から成る特徴ベクトルを生成する特徴ベクトル生成手段 (73) と、

前記帰属された分類を使用して特徴ベクトルを特徴空間においてクラスタリングするクラスタリング手段（77）と、を含み、

前記特徴ベクトル生成手段（73）によって生成される前記n個の要素から成る特徴ベクトルが対応するn次元特徴空間を定義し、

前記クラスタリング手段（77）が、ミニマクスサーチを用い、前記帰属された特徴分類に基づいてn次元特徴空間のツリー状階層分解を定義する手段を含み、特徴空間の前記ツリー状階層分解が、前記分類モデルから成ることを特徴とする統計分類モデル生成装置。

【請求項32】請求項31記載の統計モデル生成装置において、

前記クラスタリング手段（77）が、各最終特徴セルが同一分類に対応する特徴ベクトルのみを含むか、空であるか、前記分解特徴空間に対する定義済みの最小セルサイズであるよう、n次元特徴空間の階層分解を定義するように実施されることを特徴とする統計分類モデル生成装置。

【請求項33】請求項32記載の統計分類モデル生成装置において、

前記クラスタリング手段によって用いられる前記ミニマクスサーチが、特徴空間を2のべき乗によって選択的に分解する手段を含むことを特徴とする統計分類モデル生成装置。

【請求項34】請求項31記載の統計分類モデル生成装置において、

n次元特徴空間の前記ツリー状階層分解を前記画像処理装置に転送する参照手段（70）を含むことを特徴とする統計分類モデル生成装置。

【発明の詳細な説明】

【0001】

【産業上の利用分野】本発明は、一般的に静止画像用または動画像用の特徴分類技法に係り、より具体的には、空間的に分類される多次元特徴空間の新規ベクトル分類モデルを用いる、監視統計パターン認識を採用した特徴分類システムとその方法に関する。

【0002】

【従来の技術】光学的走査検出及び電子的欠陥検出の使用が引き続き増加する中、自動不良分類識別が、利用可能な技術となった。パターン認識は、物体または事象を、複数のあらかじめ指定されたカテゴリーの1つに帰属するため、特徴分類という課題にも適用が可能である。それぞれの不良（または特徴）は、画像中の結合した領域として出現し、それぞれの不良は、あるカテゴリーに帰属される。

【0003】パターン認識（PR）には、構造パターン認識と統計パターン認識の2種類がある。構造パターン認識では境界表現（BREP）として知られる特徴の形状の表現を使用するのに対し、統計パターン認識ではそ

れぞれの特徴の特性を含む数値または測定値の配列を使用し、この数値情報は、特性ベクトルと呼ばれる。しかしながら、統計パターン認識では映像をその表現から再現することはできない。しかし、特性ベクトルは、BREPよりも、対象をコンパクトに表現することができる。いずれの方法においても、目的は、分類装置、すなわち、自動的に画像を処理し、それぞれの特徴に対する分類を生成する器械を作製することである。

【0004】構造パターン認識では、分類子は形式言語理論に基づいている。BREPは処理され、境界におけるベクトルの長さと方向を表す一連の記号になる。これらの記号の連続を含む文字列の集合が言語である。言語を記述する数学的体系である文法は、特徴の構造または境界を、記号の順番のある組合せとして記述する。この文法から構成される識別子は、コンピュータ言語文を識別し、区別するのに用いられるコンピュータ言語コンパイラのように動作する。たとえば、図6のボックスは言語として考えることができる。ここに示されているように、 $L = \{ a_n, b_n, c_n, d_n \mid n \geq 1 \}$ は、各辺の長さが“1”以上のボックスを記述する言語である。

【0005】

【発明が解決しようとする課題】現実の問題においては、特徴または不良には正確な記述がないため、コンピュータ言語を構文解析するよりも、問題はより困難となる。現実的な問題を取り扱うことのできる構造識別子は、複雑な文脈に敏感な文法または確率的文法に基づき、高度なデータの複雑性と変動に対処できなければならない。このため、構造パターン認識は、通常の技術状況においては、容易には実現できない。

【0006】これに対して、統計パターン認識では、統計的判断理論に基づいた識別子を用いる。統計パターン認識にはいくつかの異なった種類が存在するが、一般的には、監視分類と非監視分類と呼ばれる、2つの主要な方法がある。

【0007】監視分類では、専門家がサンプルの各要素のカテゴリーを区別した際に形成されたラベル付きのトレーニングサンプルを使用する。確率分布が推定されるか、識別子がトレーニングサンプルから直接作成される。専門家は、データを調べ、特徴のそれぞれにラベルを付けなければならない。（ここに記載した新規のパターン認識法では、監視分類を使用する。）トレーニングサンプルにラベルを付ける作業は、グラフィカルインターフェースを附加して専門家のデータとの対話を取り扱いを容易にすることにより、簡便化が可能である。

【0008】非監視分類ではラベル付きトレーニングサンプルは使用しない。この方法では、識別子が前提となるデータのありのままの確率分布を学習する必要があるが、これは困難な問題であることが多い。しかしながら、非監視分類では、十分に大きなトレーニングサンプルを蓄積するという、時には長くなるプロセスを必要と

せず、このサンプルの要素を区別するという作業は必ずしも必要ない。本方法は、データの変更にシステムを適応させることにより、監視分類を拡張するのに有用である。

【0009】前述の方法に加え、統計パターン認識では、パラメトリック法とノンパラメトリック法という、2つの主要な方法を採用している。パラメトリック法では、前提となる現実のデータの確率分布を仮定する。ノンパラメトリック法では、このような仮定は行わない。

【0010】分布が正規分布またはガウス分布といった、一般的な形式の1つであることが既知である場合、パラメトリック法が一般に用いられる。分類子は、サンプルデータから決定される既知の事前分類と同時確率分布による、ベイズの法則に基づいて生成される。次いで特定の特徴が既知の分類関数の統計と比較され、これらを分類する。

【0011】現実的な状況では、データは正規分布や他の周知の分布に従来通り一致しない場合が多い。分類区分の分布は多様相、すなわち、2つ以上のピークが不良カテゴリーの分布に存在する様相となる（たとえば、図7を参照）。図7の例のように、スポット様不良は円形で、ほぼ等しい長さと幅により、容易に識別されるが、すべてスポットとして知られている、比較的小さい不良や大きな不良もある。この例では、スポットは周囲の長さに対する面積の比によってより良く識別される。周囲の長さに対する面積の比は、円形のスポットの大きさが変化してもほぼ一定である。この例に対応するためには特別な識別子を作成することも可能であるが、汎用性のある方法が必要である。

【0012】ノンパラメトリック法では、上記の問題に対し、判定関数または分類子をトレーニングサンプルから直接生成するという、より一般的な解決法を提供している。こうすることにより、このような方法ではパラメータを推定する問題を回避し、濃度関数に対して推定される形式を無視している（下記に説明するように、本発明はノンパラメトリック法から成る）。

【0013】ノンパラメトリック法の主な問題点の1つは、次元が増大するのに従い、必要な記憶量と計算量が指数的に増加してしまうことである。特徴が大量の測定値（または要素）で記述された場合、周知の方法が使用された場合に、問題は非常に大きくなる（本発明の技法では、特徴空間を2の累乗によって反復して割ることにより、記憶空間は、2を底とする対数分増加するだけなので、問題がより処理しやすくなる）。

【0014】

【課題を解決するための手段】簡単に説明すると、一態様において、複数の特徴を有するサンプルテスト画像から統計分類モデルを生成する方法が提供される。対応する画像処理システムにより、統計モデルが実時間監視特徴分類に用いられる。モデルを生成する方法は、複数の

特徴を有するサンプルテスト画像を画像化し、それらのデジタル画像表現を生成するステップと、そのデジタル画像表現を使用して独自の分類を同一タイプの選択された特徴に帰属するステップと、分類された各特徴に対してn個の要素から成る特徴ベクトルを生成するステップと、帰属された分類を使用して特徴ベクトルを特徴空間においてクラスタリングするステップと、新規パターンを実時間で特徴分類する間の画像処理システムによるアクセスに備え、n次元特徴空間の階層的分解を記憶するステップとを含む。ここで、n個の要素から成る特徴ベクトルは、対応するn次元特徴空間を定義し、クラスタリングはミニマクスサーチを用い、帰属された特徴分類に基づいてn次元特徴空間のツリー状階層分解を定義する。

【0015】別の態様においては、本発明は、監視統計分類装置を使用してウェブの特徴を分類する実時間画像処理方法を含む。統計分類子は、異なる特徴タイプが階層ツリーの異なる特徴空間セルでクラスタリングされるn次元特徴空間のツリー状階層分解から成る。本方法は、ウェブを画像化し、そのデジタル画像表現を生成するステップと、監視統計分類装置を参照し、画像化された特徴を、n次元特徴空間のツリー状階層分解の対応する特徴空間セル内に自動的に配置するステップと、階層ツリーに対して配置された特徴ベクトルに基づいて画像化特徴に関する統計を蓄積するステップとを含む。ここで、画像化操作は、ウェブの画像化されたそれぞれの特徴に対するn次元特徴ベクトルを生成するステップを含む。また、前記配置ステップは、特徴ベクトルを含む階層ツリーの最小セルに対して特徴空間の階層分解を探索するステップを含む。また、蓄積された統計は、対応するウェブの特徴に対する特徴タイプ分類を含む。

【0016】さらに、本発明の別の態様では、監視統計分類装置を使用してウェブの特徴を分類する実時間画像処理システムが提供される。本統計分類装置は、異なる特徴タイプが階層ツリーの異なる特徴空間セルにクラスタリングされるn次元特徴空間のツリー状階層分解から成る。本システムは、ウェブのデジタル画像表現を生成する画像化手段を含む。本画像化手段は、選択されたウェブの特徴に対するn次元特徴ベクトルを含む。実時間で監視統計分類装置にアクセスし、特徴ベクトルを、n次元特徴空間のツリー状階層分解の対応する特徴空間セル内に自動的に配置する参照手段も提供される。各配置された特徴ベクトルに対し、配置手段は、対象となる特徴ベクトルを含む階層ツリーの最小セルに対して特徴空間の階層分解全体を探索する探索手段を含む。最後に、統計蓄積手段が、階層ツリー内の配置に基づき、選択されたウェブの特徴に関する統計を蓄積する。本統計は、各配置された特徴ベクトルに対し、対応するウェブの特徴の特徴タイプ分類を供与する。

【0017】様々な付加的な方法及びシステムの拡張に

についても説明し、請求するものとする。

【 0 0 1 8 】

【作用】前述の説明から明らかなように、サンプリングしたテスト画像（または、好適には、複数のサンプリングしたテスト画像）から統計モデルを生成する新規方法が提供される。説明した柔軟性のあるノンパラメトリック法により、オンライン画像処理システムによって深さを優先して探索される分類ツリーが、たとえば品質管理プロセスの一部として生成される。処理システムは特定の特徴ベクトルを対応する特徴空間セル内に配置する。データモデルは、一旦生成されると、所定のプロセス及び画像条件に対して、精度を保つ。生成したデータモデルは、特徴の分類において、現在までに知られているモデル化技法より効率的で正確である。技法を複数使用すること（ここでは“ハイパーツリー”と呼んだ）によって不良カテゴリーの確率分布を自動的に学習する非監視法を同時に使用することにより、更に高い精度が得られる。その結果生成したセルサイズとセルのサイズ比は、これらの中にある不良の数と共に、即座に統計的性能の質についての情報を生成する。認識の確実性は、不良分類をあらかじめ推定することによって提供される。さらに、本技法はソフトウェアでもハードウェアでも実現可能である。

【 0 0 1 9 】

【実施例】本発明のこれら及び他の目的、利点、特徴は、ある好適な実施例についての以下の次の詳細な説明を添付の図面と照合することにより、より容易に理解することができる。

【 0 0 2 0 】詳細な実施例で説明する実施例において、本発明は“ハイパーツリー”と呼ぶ。

【 0 0 2 1 】ハイパーツリー法では、各不良または特徴は、 n 個の特徴の測定値または特性を含む特徴ベクトルにより、初期に記述される。これらのベクトルは、次元の数が特徴ベクトルにおける測定値の数 “ n ” に等しい、多次元（すなわち、より詳細には n 次元）特徴空間を形成する。本発明に従う統計解析は、特徴ベクトル毎に 3 個以上の要素または測定値を取込むことにより、拡張される。本発明の方法はこの特徴空間を分解し、各不良区分に対するクラスタを形成する。データモデルはサンプルデータのクラスタから直接生成する。このデータモデルが最終的にオンラインの画像システムに転送され、新たな不良データを実時間で区分するのに使用される。

【 0 0 2 2 】アルゴリズム

ハイパーツリーのアルゴリズムでは、当該技術分野で“ミニマクスサーチ”と呼ばれる発見的サーチの一種を使用する。ミニマクスサーチは、他の区分に帰属される特徴を示すことによってハイパーキューブの純度を損なおうとする悪意のある対戦相手の存在すを想定することにより、多次元特徴空間を反復して細分化するため、ゲ

ーム理論で用いられるものに類似している。これによつて、本方法を、三次元空間を分解し、幾何学的な立体を配置及び測定するのに用いられるオクトツリーに類似した技法と結合する。オクトツリー法は、三次元から多次元（すなわち、3 次元より大きい次元）の“ハイパー空間”に拡張され、“ハイパーツリー”を形成する。この方法では、ハイパー空間における領域の純度を維持しようとしながら、空間をより小さなハイパーキューブに反復して分解する。ハイパーツリーアルゴリズムは、領域が純粹になるか、定義済みの最小セルサイズに達した時点で停止する。

【 0 0 2 3 】ハイパーキューブは、初期には、不特定の区分であると仮定され、すべての点が空である。第 1 の点が空のハイパーキューブに到達すると、キューブは 2^d 個の子ハイパーキューブに分解される。所定の区分のそれぞれの新しい点が現れ、それぞれの点が空の貧領域または異なる区分の領域に配置されると、細分化が起こる。分類された純粹なハイパーキューブに点が出現すると、そのハイパーキューブについてカウントが増加する。このプロセスは、トレーニングサンプルにおけるすべての点が読まれるまで、反復して継続する。特徴空間は個別の抽出空間であるため、細分化は、分類ハイパーツリー上のリーフノードとしての単位サイズのハイパーキューブを生成するのに十分な回数だけ反復される。ハイパーツリーは、必ず最小タイプセルに分解するわけではない。たとえば、発見的サーチを停止するのに別の基準が用いられ、最大分解レベルと呼ばれる実物大のハイパーキューブよりも大きいハイパーキューブを形成する場合がある。一般的には、不純なリーフノードは、相対するカテゴリーの点が、ハイパー空間のほぼ同じ位置に発生したこと示している。

【 0 0 2 4 】図 3 は、面積と周囲の長さによって各特徴ベクトルが構成される二次元空間における 2 つの不良カテゴリーを識別するために、特徴空間がどのように分解されるかを単純化して示した、二次元の例である。この場合には、特徴空間が分解され、それぞれのカテゴリーに対して純粹な正方形を生成している。点で示した正方形内にある点がスポットとして分類され、交差斜線領域内にある点はストリークであると分類される。何もない領域は分類されない。相対するカテゴリーの点同士が接近していると、空間はさらに小さな正方形へと分解される。しかしながら、多次元空間を描くのが困難なため、より現実的な例を示すのは困難である。長さと幅といったさらに 2 つの次元が含まれれば、その結果生成するハイパー空間をより正確に分解する。また、実際の適用においては、明確に分類できないトレーニングサンプルにおける不良または特徴を包含するため、カテゴリーゼロといった、不特定の分類が含まれる。

【 0 0 2 5 】リーフノードの数と分解のレベルは、トレーニングサンプルの品質と、生成したデータモデルが不

良カテゴリーを識別する際に有する成功率を示す。所定のカテゴリーによって占有される領域において、その他のカテゴリーの点の数の比を考慮することにより、損失関数及びリスク関数が生成される。符号化された特徴空間または生成したデータモデルは、各子ハイパーキューブの存在を示すのに 1 ビットを使用して、たとえばディスクにセーブされる。このモデルは、新規データを実時間で分類するために、オンライン画像処理プログラムによって読み込まれる。本発明に従うモデル構築の 1 つのソフトウェアの実施例の概観を下記に示す。

【0026】主プログラム：データベースからトレーニングサンプルの各特徴を読み込み、それぞれの新しい特徴を読み込んだ後、Decomposeを呼出す。

【0027】Decompose：特徴が同一タイプのものであるか、最小ハイパーキューブか、または空である場合、ハイパーキューブに特徴を付加する。ノードが初期化されていない場合には、初期化される。ノードがリーフノードでない場合、Decomposeが反復して呼出される。ノードがリーフノードであるが、最小ノードでない場合、現行の特徴と異なるカテゴリーを有するノードにおけるすべての点に対し、Try-to-Excludeが呼出される。次いで、現行の特徴としての同一のカテゴリーのすべての特徴に対し、Decomposeが反復して呼出される。

【0028】Try-to-Exclude：特徴が最小セルか、空である場合、ノードに特徴を付加する。ノードが初期化されていない場合には、初期化される。ノードがリーフノードであるが、最小ノードでない場合、同一の特徴のカテゴリーを有するノードにおけるすべての点に対し、Decomposeが呼出される。次いで、特徴と共に、Try-to-Excludeが反復して呼出される。

【0029】Traverse：データモデルの統計を蓄積する。ハイパーツリー全体を探索し、それぞれの不良カテゴリーに対し、事前確率及び事後確率、平均、分散、損失関数、リスク関数を計算する。

【0030】Printstat：Traverseによって蓄積された統計の要約を印字する。

【0031】Writeinx：ハイパーツリーを反復して降り、各子ハイパーキューブに対して 1 ビットだけが使用されている符号化形式を使用して、データモデルをディスクに書込む。

【0032】下記の擬コードは、上記に要約した主プログラムの成分を記述する擬コードを表 1 から 5 に示す。変数名はイタリック体で示す。

【0033】

【表 1】

Main program

Initialize head pointer to hyper-tree.
 Establish maximum level of decomposition.
 Determine minimum cell size for leaf-nodes.
 For n = 1 to the total number of features (N) do
 the following
 Read feature_n from Segmented Image Database
 Call Decompose (feature_n, head) which attempts
 to place feature in correct hyper-cube.
 Call Traverse to accumulate the statistics for each
 category.
 Call Printstat to print the statistics.

Decompose (feature, node)

If node is at minimum size or the maximum level of
 decomposition is reached then
 put feature in child's list of features
 else is node is leaf node then
 if there are no points of other categories in
 node then
 put feature in node's list of features
 else begin block
 find center of cell for point feature.

 if child cell corresponding to new center
 is NIL then
 make new child-cell
 call Decompose (child-cell, feature)
 for all categories $\Omega = (\omega_1 \dots \omega_k)$, $i=1 \dots k$ do
 if category of feature is not the
 same as ω_i then begin
 for all old points in node's list
 of category ω_i do
 take old point,
 oldpoint of category ω_i

【表2】

```

from list
find center of cell for
oldpoint.
if child-cell for new
center is NIL
make new child-cell
call Try-to-Exclude
(child_cell, oldpoint)
end for all
end if
end for all
end of block
else begin block
find center of cell for feature.
if child cell corresponding to new center is NIL
then
make new child-cell
call Decompose (child-cell, feature)
end of block
end of procedure Decompose.

```

```

Try-to-exclude (feature, node)
If node is minimum size or maximum level of
decomposition is reached then
put feature in node's list of features
else if node is leaf-node then
if there are no points of other categories in
node then
put feature in node's list of features
else begin block
find center of cell for feature.
if child-cell corresponding to new center is NIL
then
make new child-cell
for all points in child-cell's list
for category of feature do

```

19

20

```

take oldpoint from list
find center of cell for oldpoint
if child cell corresponding to
new center is NIL then
    make new child-cell
    call Decompose (child-cell, oldpoint)
end for all
call Decompose (child-cell, feature) to push
    feature down list.
end of block
else begin block
    find center of cell for point feature.
    if child-cell corresponding to new center is NIL
    then
        make new child-cell
        call Try-to-Exclude (child-cell, feature)
    end of block
end of procedure Try-to-Exclude.

```

Traverse

```

For category = 0 to maximum feature type do
    Initialize area and count to 0
    For i = 0 to Max Dimension Do
        Initialize mean and variance to 0
        Initialize risk, apriori and aposteriori to 0
    For level = 0 to Maximum decomposition level do
        Initialize area and count to 0
    If root node is not barren
        bump level
        For n = 0 to 2dim do
            if child cube (n) exists
                call follow branch to accumulate
                    sum for mean
            calculate mean
            for category = 0 to maximum feature type do
                if count for this cat is 0

```

```

mean = 0
else
mean = sum/count [category]
calculate aposteriori
if volume_total[category]
is 0
aposti = 0
else
aposti = count/volume
total
Do the traversal again to get sum2
for variance
for n = 0 to 2dim
if root is not barren
call follow again
Now calculate standard deviation
and apriori
for category 1 to maximum feature type do

apriori = count/total
for i = 0 to DIM
SD[i] = sqrt [sum2/total count]
For category 2 to maximum feature type DO
if category 1 = category 2
expected loss [category 2] = 0
else
expected loss = vol_count
[category 1 * category 2]
/ category_count * apriori
for category 1.
risk = 1 category_count/volume
total [category 1].
```

Follow branch

If this note is barren it is a leaf node

sum area

23

```

find the category of this cell
sum feature vectors into array
else
for n = 0 to 2DIM
    if progeny [n] exists
        call follow branch

Follow again
if this node is a leaf node
for each vector in this cell
    sq_accum = sq_accum + (vector[i] -
mean[i])2 Used to calculate variance
and standard deviation

else
for n = 0 to 2DIM

```

ハイパーツリーの実施

図4について説明する。管理分類のハイパーツリー法では、符号化スレッショルドバイナリ画像の形式で実時間画像システムより生成する大きなトレーニングサンプルが必要である(20)。“符号化スレッショルドバイナリ画像のトレーニングサンプル”。次いで結合された領域または特徴が、結合性解析を実行することによって画像から抽出される(22)。“結合領域の抽出”。それぞれの結合領域は頂点のリストか、境界記述か、それを囲む多角形かによって記述される。頂点の各リストは、独自の識別子または特徴番号によって索引が付けられたデータベースに記憶される(24)。“結合領域のデータベースへの記憶”。

【0034】幾何学的測定値がデータベースの各領域より取得され、特徴ベクトルと呼ばれる整数の配列を形成する(26)。“幾何学測定値の取得と特徴ベクトルの形成”。この配列は、たとえば、多次元ハイパー空間が定義される、xとyの位置、幅、長さ、周囲の長さ及び面積を含む。各特徴ベクトルは、特徴番号によって索引付けされるデータベースに記憶される(28)。“特徴ベクトルの保存”。本ステップの後、データベースは、トレーニングサンプルにすべての特徴を記述する情報を含むことになる。

【0035】ハイパーツリーにおけるような監視分類について、トレーニングサンプルにおける対象の各特徴の事前分類を設定することが必要である。すべての特徴の映像がグラフィックワークステーションのスクリーン上に表示され、専門家がそれをスクロールし、すべての対象となる特徴を適切な分類によって標識することができる(30)。“特徴ベクトルの分類”。

【0036】ハイパーツリーはデータベースから分類された特徴のサンプル集合を読み込み、分類子またはデータモデルを生成し、これを記憶する(32)。“ハイパーツリーを呼び出し、データモデルを形成”。これは、多次元

20

30

40

50

24

ハイパーツリーをメモリに作成し、特徴空間をサンプルデータの分類によって指定されたように分解することによって実施される。各不良カテゴリーに対する、事前確率、事後確率、平均、ばらつき、損失関数、リスク関数は、好適にはすべて計算される(そして印字される)。損失関数は、所定の特徴に対して、性質の真の状態が異なる分類のときに間違った分類を選択する確率である。リスク関数は、特定の間違った分類を選択する確率である。

【0037】図5は、上記に要約したサブルーチンを使用した、具体的なハイパーツリー処理方法を示している。ハイパーツリー処理は、ポインタを主プログラムに対して初期化することによって開始する(40)。“ポインタをハイパーツリーに対して初期化”。その後、分解の最大レベルが決定され(42)。“分解の最大レベルを決定”、最小セルサイズが決定される(44)。“リーフノードに対して最小セルサイズを決定”。それぞれの記憶された特徴に対して分解されたサブルーチンが呼出され、適切なハイパーキューブに特徴を配置する(46)。“それぞれの特徴に対してデータベースから特徴を読み込み、Decompose (Feature, Head) を呼び出し、適切なハイパーキューブに特徴を配置”。各特徴が配置されると、分類ツリーは全体が探索され、各分類に対する統計を蓄積し(48)。“Traverseを呼び出し、各カテゴリーに対する統計を蓄積”、統計が印字される(50)。“Printstatを呼び出し、統計を印字”。

【0038】例として、表6～17には、動画映像ファイル上の2つの不良タイプのサンプルについてハイパーツリーを実施した実施例の出力リストを示す。本表は、特徴ベクトルにおける各要素に対する、特徴空間の区画の範囲と、算出された損失関数と、リスク関数、平均、標準偏差を示している。

【0039】

【表6】

カテゴリー	レベル	点	面積
すべて	0	0	0
0		0	0
1		0	0
2		0	0
3		0	0
4		0	0
5		0	0
6		0	0
7		0	0
8		0	0
すべて	1		2048
0		1	2048
1		0	0
2		0	0
3		0	0
4		0	0
5		0	0
6		0	0
7		0	0
8		0	0
すべて	2		0
0		0	0
1		0	0
2		0	0
3		0	0

【表7】

27

28

4		0	0	
5		0	0	
6		0	0	
7		0	0	
8		0	0	
すべて	3		5 1 2	
0		0	0	
1		1	5 1 2	
2		0	0	
3		0	0	
4		0	0	
5		0	0	
6		0	0	
7		0	0	
8		0	0	
すべて	4		0	
0		0	0	
1		0	0	
2		0	0	
3		0	0	
4		0	0	
5		0	0	
6		0	0	
7		0	0	
8		0	0	
すべて	5		0	
0		0	0	
1		0	0	
2		0	0	

【表8】

29

30

3		0	0
4		0	0
5		0	0
6		0	0
7		0	0
8		0	0
すべて	6		0
0		0	0
1		0	0
2		0	0
3		0	0
4		0	0
5		0	0
6		0	0
7		0	0
8		0	0
すべて	7		32
0		2	32
1		0	0
2		0	0
3		0	0
4		0	0
5		0	0
6		0	0
7		0	0
8		0	0
すべて	8		192
0		1	48
1		1	48

【表9】

31

32

2	2	96	
3	0	0	
4	0	0	
5	0	0	
6	0	0	
7	0	0	
8	0	0	
すべて	9	160	
0	1	80	
1	1	32	
2	1	48	
3	0	0	
4	0	0	
5	0	0	
6	0	0	
7	0	0	
8	0	0	
すべて	10	104	
0	1	84	
1	1	24	
2	1	4	
3	0	0	
4	0	0	
5	0	0	
6	0	0	
7	0	0	
8	0	0	

各カテゴリーに対するサンプル統計

カテゴリー： 0

統計配列

	幅	長さ	面積	周囲の長さ	PJ長
平均	2.604	0.788	23.074	6.600	1.794
標準偏差	4.45	4.65	556.91	17.79	4.66

【表 11】

予想損失

カテゴリー	損失
0 損失	0. 00
1 損失	0. 00
2 損失	0. 00
3 損失	0. 00
4 損失	0. 00
5 損失	0. 00
6 損失	0. 00
7 損失	0. 00
8 損失	0. 00

面 積	カウント	事前確率	事後確率	リスク
2292	860	0. 96	1. 00	0. 00

各カテゴリーに対するサンプル統計

カテゴリー： 1

統計配列

	幅	長さ	面積	周囲の長さ	PJ長
平均	11.200	11.267	94.133	55.200	16.600
標準偏差	5.0	19.39	183.12	85.48	34.22

【表13】

予想損失

カテゴリー	損失
0 損失	0.26
1 損失	0.00
2 損失	0.00
3 損失	0.00
4 損失	0.00
5 損失	0.00
6 損失	0.00
7 損失	0.00
8 損失	0.00

面積	カウント	事前確率	事後確率	リスク
616	15	0.02	0.79	0.21

【表14】

各カテゴリーに対するサンプル統計

カテゴリー： 2

統計配列

	幅	長さ	面積	周囲の長さ	PJ長
平均	13.882	8.708	77.176	49.059	10.765
標準偏差	3.12	1.86	25.04	8.58	2.63

【表15】

予想損失

カテゴリー	損失
0 損失	0. 0 0
1 損失	0. 0 0
2 損失	0. 0 0
3 損失	0. 0 0
4 損失	0. 0 0
5 損失	0. 0 0
6 損失	0. 0 0
7 損失	0. 0 0
8 損失	0. 0 0

面積	カウント	事前確率	事後確率	リスク
148	17	0. 0 2	1. 0 0	0. 0 0

各カテゴリーに対するサンプル統計

カテゴリー : 3

統計配列

	幅	長さ	面積	周囲の長さ	P J 長
平均	0.000	0.000	0.000	0.000	0.000
標準偏差	0.000	0.000	0.000	0.000	0.000

【表17】

予想損失

カテゴリー	損失
0 損失	0. 00
1 損失	0. 00
2 損失	0. 00
3 損失	0. 00
4 損失	0. 00
5 損失	0. 00
6 損失	0. 00
7 損失	0. 00
8 損失	0. 00

面積	カウント	事前確率	事後確率	リスク
0	0	0. 00	0. 00	0. 00

リストの第1の部分は、特徴空間の分解を示している。“面積”は、実際にはハイパーキューブの端のサイズである。面積が大きい場合は、ハイパー空間の分解が少なく、特徴クラスタがより明瞭であることを示している。各カテゴリーの特徴の数は、分解の各レベルについて示してある。

【0040】リストの第2の部分には統計が示されている。事前確率は、全サンプルの所定のカテゴリーの特徴の数に基づいている。損失関数、リスク関数、事後確率は、特徴クラスタの“純度”の決定に基づいている。

【0041】プログラムDecision (以下で説

明) は、分類子またはデータモデルを読み込み、新規特徴ベクトルの各ファイルを分類するのに用いる。まず、ディスク上のコンパクトな表現から、ハイパーティリーをメモリに作成する。次いで、Decisionはファイルのすべての特徴ベクトルを読み込み、分類を生成する。これは、特徴がリーフノードハイパーキューブに当たる場合に、分類を帰属するハイパーティリー全体を探索することによって実施される。

【0042】ハイパーティリーの導出

各不良カテゴリーに対する事後確率と、算出損失関数

と、算出リスク関数に対する式の導出を本セクションに

示す。ハイパーツリーにおいて、実際の分類子またはデータモデルは、分類子が特徴空間の区画から直接生成し、確率分布と濃度関数の推定を無視する、ノンパラメトリック法に基づいている。推定確率分布と濃度関数はトレーニングサンプルから計算することができるが、これらの推定はハイパーツリープログラムでは使用されない。事後確率に対するハイパーツリーの式は、 k_i / k である。 k_i はタイプ i のサブボリューム V における特徴の数、 k はサブボリューム V における特徴の全数である。特徴空間が既にハイパーキューブに最適に分解されているものと仮定すると、この区画が導出を示す。

【0043】ハイパーツリー法では、特徴空間が実際の特徴空間の個別サンプリングであり、区画がバイナリで

$$x = (x_1 \dots x_d), \text{ forming hyper-space } R_d.$$

を有する、複数の特徴ベクトル X から成る。

【0045】サンプルサイズが十分に大きく、所定のカテゴリ ω_j として発生する不良の事前確率が正確に予測できるものとすると、確率 $P(\omega_j)$ は次式となる。

【0046】

【数3】

$$p(\omega_j) = \frac{n_j}{N}$$

n_j はカテゴリ j の点の数、 N は点の総数である。

【0047】特徴 x がハイパー空間 R の領域内にある確率 P を仮定すると、

【数4】

$$p = \int_{R} p(x') dx'$$

となる。 dx' はボリューム要素である。

【0048】

【数5】

$$P \equiv p(x)V$$

V はハイパー空間の領域 R のボリュームである。

【0049】Parzen windows や最近傍法といったノンパラメトリック技法では、 d 空間におけるハイパーボリュームは、所定のカテゴリ ω_j の一定数の特徴を含むのに十分なサイズとなるよう、選択される。ここで説明した方法のハイパーツリーでは、ハイパーボリューム V は、 k 個の点を含むよう選択される。ここで、 $k \geq k_j$ であり、 k_j は、ボリューム V におけるカテゴリ j のすべての不良である。空間平均条件付確率濃度 $p(x | \omega_j)$ は、

【数6】

$$p(x | \omega_j) = \frac{k_j/N}{V}$$

である。

【0050】ベイズの法則によれば、 $p(\omega_j) p(x | \omega_j) = p(x) p(\omega_j, x)$ である。ここで、

あるため、いくぶんサンプリングエラーが生じる。このサンプリングエラーは小さいものと見なされ、考慮されない。また、データはサンプリングされた画像からとられた測定値から成り、特徴空間は最小ハイパーキューブサイズの 1 未満には分解されないため、サンプリングエラーは無視できる。

【0044】 n 個のカテゴリの集合を考慮すると、

【数1】

$$\Omega = (\omega_1 \dots \omega_j \dots \omega_s), 1 \leq j \leq s.$$

サンプル集合は、それぞれが d 個の要素：

【数2】

$$x = (x_1 \dots x_d), \text{ forming hyper-space } R_d.$$

【数7】

$$p(x) = \sum_{i=1}^s p(x | \omega_i) p(\omega_i)$$

20 である。

【0051】したがって、ベイズの法則を事後確率を算出するのに適用することができる。

【0052】特徴がタイプ x である場合、誤った決定をするコストを最小化する次式の決定法則が適用される。

【0053】

【数8】

$$p(\omega_j | x) = \frac{p(x | \omega_j) p(\omega_j)}{\sum_{i=1}^s p(x | \omega_i) p(\omega_i)} = \frac{k_j}{k}$$

この方法で使用される決定法則は、特定のサンプル空間における総リスクを最小化する。これがベイズリスクであり、実現可能な最小リスクである。

【0054】真の分類が ω_j であるときに作用 α_i がとられると、予測損失は

【数9】

$$\lambda(\alpha_i | \omega_j)$$

40 となる。

【0055】この予測損失関数は、ボリューム V におけるタイプ i の点の数により、トレーニングサンプルから推定することができる。

【0056】

【数10】

$$\lambda(\alpha_i | \omega_j) = \frac{k_i}{k_j}$$

特徴 x に対して作用 α_i をとる総条件付リスク $R(\alpha_i | x)$ は、

【数11】

$$R(\alpha_i | x) = \sum_{i=1}^s \lambda(\alpha_i | \omega_i) p(\omega_i | x) = \frac{k_i}{k}$$

となる。

【0057】性能分析

本セクションでは、ハイパーテリーのアルゴリズムを分析し、統計パターン認識を実施するのに用いられる他のアルゴリズムと比較する。さらに、ノンパラメトリック法とパラメトリック法の選択に関連する、実行時間と記憶スペースの考慮について説明し、ハイパーテリー処理の具体的な性能向上について、他のノンパラメトリック法と比較して説明する。

【0058】パラメトリック法では、必要な記憶スペースがノンパラメトリック法の場合よりも小さい。パラメトリック法では、基になる確率分布関数は既知であり、判別関数は事前関数と区分条件付濃度関数から計算できるため、特徴空間の実際の表現を記憶する必要はない。したがって、全記憶スペースの必要量は最小化される。ハイパーテリーのメモリの使用は、多次元分類子を効率的に2進符号化することによって最小化され、今日のコンピュータにおいてはメモリコストが減少しているため、記憶空間の必要量を考慮することは重要ではなくなりつつある。

【0059】最近傍法またはParzen windowsといった、ノンパラメトリック法では、高データ量に対して計算の必要量は抑制される。各特徴、すなわち、ハイパー空間における点に対して、複数の近傍の点を囲み、近傍における大多数の点を分類することができるよう十分大きなボリュームが選択されなければならない。これは、 $O(n^2)$ で実行される。ここで、nは1つのカテゴリ一分類子に対する特徴の数である。2つのカテゴリ一分類子に対しては、これは $O(n^4)$ で実行され、3つのカテゴリ一分類子に対しては、 $O(n^8)$ で実行される。c個の分類に対しては、 $O(n^{2c})$ で実行される。

【0060】ハイパーテリーでは、特徴空間は連続したバイナリ区間によって分解される。したがって、特徴空間が完全に分解される場合の、1つのカテゴリ一分類子に対する最悪の場合の実行時間は、 $O[n \log(n)]$ である。ここで、nは特徴の数である。次元が大きくなても、実行時間は大幅には増加しない。特徴ベクトルにおけるすべての余剰要素に対しては、特徴毎にもう1つの比較演算があるだけなので、ファクタは一次である。複数のカテゴリに対しては、効果は次のようになる。2つのカテゴリに対して、ハイパーテリーは $O[n^2 \log(n)]$ で実行され、3つのカテゴリに対しては $O[n^3 \log(n)]$ で実行され、c個のカテゴリに対しては $O[n^c \log(n)]$ で実行される。非常に数の多い独自のカテゴリに対してはハイ

パーテリーの性能は低下するが、性能はその他の方法ほど急速には低下しない。

【0061】ハイパーテリーを用いた演算不良分類システム

本セクションでは、図1にブロックダイアグラムで示した、オフラインのワークステーション（監視統計分類装置60）と、ニューヨーク州Rochesterのイーストマンコダック社EKTRON応用画像社により市販されている、80で示したVEREDUSTM実時間表面欠陥検出解析システムを使用し、カテゴリーによって不良を識別し、分類する、完全なシステムについて説明する。本システムの核心部にあるのは、統計パターン認識のハイパーテリー法である。

【0062】VEREDUSTMシステム（画像処理装置80）は、表面の欠陥または不良、あるいは刻まれた欠陥または不良を、ウェブ62に基づくコーティング、ブレーティング、或いは同様の処理によって光学的に検出するのに用いられる、専用高速パイプライン画像処理システムである。VEREDUSTMは、1つまたはそれ以上のリニア光学画像センサ（画像化手段64）に接続することができ、オペレータ（図示せず）に対し、不良タイプ及び統計を統計的に作表したレポート（統計蓄積手段72）を生成する。

【0063】ハイパーテリーは、VEREDUSTM実時間表面欠陥検出解析システム（画像処理装置80）に、実時間で走査中に、移動するウェブ上の不良を認識するのを“教える”のに使用されるオフライン分類システム（監視統計分類装置60）の一部である。本プログラムは、リレーショナル不良データベース74を中心としたシステムの他のプログラムと統合されている。本システムは、次のプログラムから成る。（1）Connect

（特徴ベクトル生成手段73）：画像を分解し、分解した画像情報をリレーショナル不良データベース（統計分類モデル74）に挿入する。（2）Geo75：特徴ベクトルを形成する不良の幾何学的測定値をとり、リレーショナル不良データベース（統計分類モデル74）に追加する。（3）Classify（帰属手段76）：事前分類または既知の分類を“トレーニングサンプル”的に帰属するため、オペレータによって実行されるプログラム。（4）ハイパーテリー（クラスタリング手段77）：前述したように、特徴空間を分解し、“OFC LAS Data Model”と呼ばれる分類子、すなわち分類モデルを形成する。また、VEREDUSTM実時間表面欠陥検出解析システム（画像処理システム80）には、データモデルOFC LASをとり、それを未分類データとして新規に適用する、すなわち、事後分類演算を実施する、第5のプログラムDecision

（参照手段70）もある。

【0064】VEREDUSTM実時間表面欠陥検出解析システム（画像処理システム80）には、走査した対象

画像の一部を、Yグループ符号化 6 6 という圧縮形式で取得するための専用モードがある。このYグループ符号化された画像は、VEREDUSTM 実時間表面欠陥検出解析システム（画像処理システム 80）が共用VMEバスメモリ、シリアルポート、tcp / ip のいずれかを装備していれば、これらを介して、VEREDUSTM 実時間表面欠陥検出解析システム（画像処理システム 80）からオンライン分類システム（監視統計分類装置 60）に移動することができる。

【0065】1. Connect (特徴ベクトル生成手段 73) は、圧縮画像を取得する。これは一般に、画素当たり 1 ビットといったバイナリ画像であるが、画素当たりそれ以上のビット数を有することもある。各共通部分を各画像画素値の変化によって記録する際に、画像はYグループ符号化から解凍される。次の各走査線によって物理的に別々の特徴に分解される。実際には、これによって画像中の各特徴の境界が見出される。頂点の数を最小必要数にまで減少させた後、各特徴は、すべての特徴の負及び正の空間の輪郭または境界を記述する頂点の x, y の対のリストとして、データベースに記憶される。すなわち、外側の境界は、ホールまたは負の領域の境界と共に記憶される。これらの特徴のそれぞれは、ユニークキーにより、データベースに記憶される。

【0066】2. Geo は、データベースから特徴を読み込み、それぞれの特徴の幾何学的測定値をとる。これらの測定値は、特徴ベクトルと呼ばれるもの、すなわち、これらの特徴のそれぞれの幾何学的特性を記述する数のリストを形成する。特徴ベクトルは、最も広い点の幅、最も長い点の長さ、周囲の長さ、ホールを除いた面積を含むことができる。また、オプションとして、x, y の座標位置、重心、すなわち重力の中心、射影長を含むことができる。Geo は、各特徴に対する特徴ベクトルをデータベースに追加し、Connect (特徴ベクトル生成手段 73) によって取得された境界にキー入力する。

【0067】3. Classify (帰属手段 76) は、データベースで見出された境界頂点リストを使用して原画の画像表現をオンラインワークステーションのスクリーン上に描画し、使用者が対象となる特徴をマウスで指定して選択できるようにする。プログラムの使用者は対象となる各特徴にたいして分類を選択することができる。このようにして、事前分類が決定される。これらの事前分類のそれぞれは、データベースに記憶され、前述の境界リストと特徴ベクトルにキー入力される。

【0068】4. ハイパーテリープログラムは、分類子、すなわち分類モデルを作成するために実行される。

$$\text{maxcubes} = \text{level} \cdot (1 < \text{dim})$$

$$2^{\text{dim}-3}$$

となる。

【0080】daughtermask に必要なバイト数は、

このモデルは OFCLAS データモデルという。このモデルを生成するためにハイパーテリーに使用される方法は、詳細に前述した。本モデルは上述のインターフェースのうちの 1 つを用いて VEREDUSTM 実時間表面欠陥検出解析システム（画像処理装置 80）に転送される。

【0069】5. Decision は、モデルに従って新規データを分類する。オンラインシステム上で実行され、結果を確認またはチェックするバージョンもある。

【0070】図 2 は、“OFCLAS” と呼ばれる、本発明に従って構築されたデータモデル構造の 1 実施例を示している。標準化された名前と数が、各測定値に好適に割当てられる。図 2 のサンプルデータモデルでは、次の用語が用いられる。

【0071】Dim : データモデルの次元数。これは、特徴ベクトルの要素の数に等しい。

【0072】Level : 本モデルで使用された分解レベルの数。

【0073】Class : 分類。

【0074】MAXCLASS : 可能な分類またはカテゴリーの最大数。

【0075】Risk : 実際のカテゴリーが i であるときにカテゴリー j を選択する場合の損失関数（またはコスト）。これは、各要素が浮動小数点数である MAXCLASS 要素の二次元配列として実行される。

【0076】Loss : カテゴリーを間違って選択する場合の損失関数（またはコスト）。浮動小数点数の配列として表される。

【0077】Daughtermask : マスクは、すべての可能な daughter に対して 1 ビットを有し、daughter の最大数は 2^{dim} である。ビット位置における 1 は daughter が存在することを示し、0 は daughter が存在しないことを示す。常に Daughtermask がルートノードにある。他のノードでは、ノードの分類が > 0 の場合のみ Daughtermask が存在する。

【0078】Cube : 次のレベルに対する分類と Daughtermask を含むデータ構造。キューブがリーフノードの場合、分類は > 0 となる。分類が 0 未満の場合、Daughtermask が続く。データ構造は反復的であり、キューブの最大可能数は、分解レベルに 2 の次元数 dim 乗を掛けたものに等しい。これを式で表すと、

$$\text{maxcubes} = \text{level} \times 2^{\text{dim}}$$

となる。

【0079】“C” で表すと、キューブの最大数は、

$$\text{maxcubes} = \text{level} \cdot (1 < \text{dim})$$

$$2^{\text{dim}-3}$$

である。

【0081】“C” で表すと、daughtermask

k は、

char daughtermask [1<< (dim-3)]

と定義される。

【0082】キューブの実際の数は、一般的に最大数よりもはるかに小さい。これは、分類子の質、すなわち、モデルを作成するのに使用されたトレーニングサンプル中のオリジナルデータの統計的分布に関連する。

【0083】データモデルのトップには、ヘッダがある。その次にあるのは損失関数配列、次いでリスク関数配列と続く。最後には、キューブがルートキューブからリーフキューブの順に見られる。

【0084】本発明の特定の実施態様を、添付の図面に示し、詳細な説明において説明してきたが、本発明はここに記載した特定の実施態様に限定されるものでなく、本発明の範囲から逸脱することなく、様々な変更、修正、置換が可能であるものとする。特許請求の範囲には、このような修正をすべて含むものとする。

【0085】

【発明の効果】前述の説明から明らかなように、サンプリングしたテスト画像（または、好適には、複数のサンプリングしたテスト画像）から統計モデルを生成する新規方法が提供される。説明した柔軟性のあるノンパラメトリック法により、オンライン画像処理システムによって深さを優先して探索される分類ツリーが、たとえば品質管理プロセスの一部として生成される。処理システムは特定の特徴ベクトルを対応する特徴空間セル内に配置する。データモデルは、一旦生成されると、所定のプロセス及び画像条件に対して、精度を保つ。生成したデータモデルは、特徴の分類において、現在までに知られているモデル化技法より効率的で正確である。技法を複数使用すること（ここでは“ハイパーツリー”と呼んだ）によって不良カテゴリーの確率分布を自動的に学習する非監視法を同時に使用することにより、更に高い精度が

得られる。その結果生成したセルサイズとセルのサイズ比は、これらの中にある不良の数と共に、即座に統計的性能の質についての情報を生成する。認識の確実性は、不良分類をあらかじめ推定することによって提供される。さらに、本技法はソフトウェアでもハードウェアでも実現可能である。

【図面の簡単な説明】

【図1】本発明のシステムの1実施例のブロックダイアグラム図である。

【図2】本発明に従って構築されたデータモデルの記憶構造の1実施例のブロックダイアグラム図である。

【図3】本発明に従う、特徴空間の二次元反復的分解の単純な例の図示である。

【図4】本発明に従う、データモデル作成中の前処理の1実施例の機能フローチャートである。

【図5】本発明に従う、“ハイパーツリー”処理の特定の実施例の機能フローチャートである。

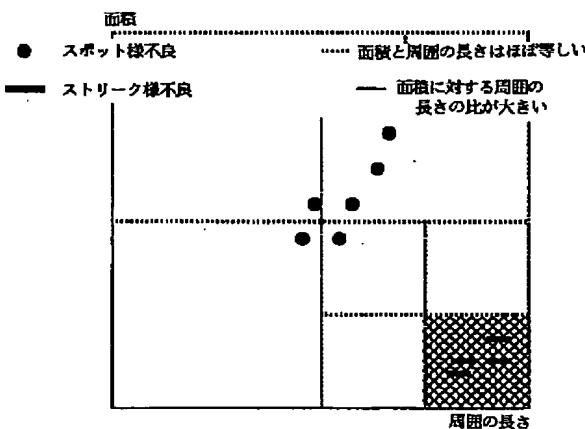
【図6】構造パターン言語表現の例である。

【図7】定義した領域において所定の分類の不良が多様相分布するサンプルのグラフ図である。

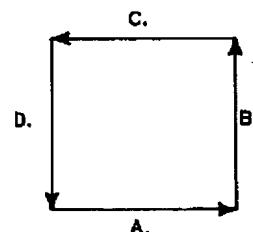
【符号の説明】

- 6 0 監視統計分類装置
- 6 2 ウェブ
- 6 4 画像化手段
- 7 0 参照手段
- 7 2 統計蓄積手段
- 7 3 特徴ベクトル生成手段
- 7 4 統計分類モデル
- 7 6 帰属手段
- 7 7 クラスタリング手段
- 8 0 画像処理装置

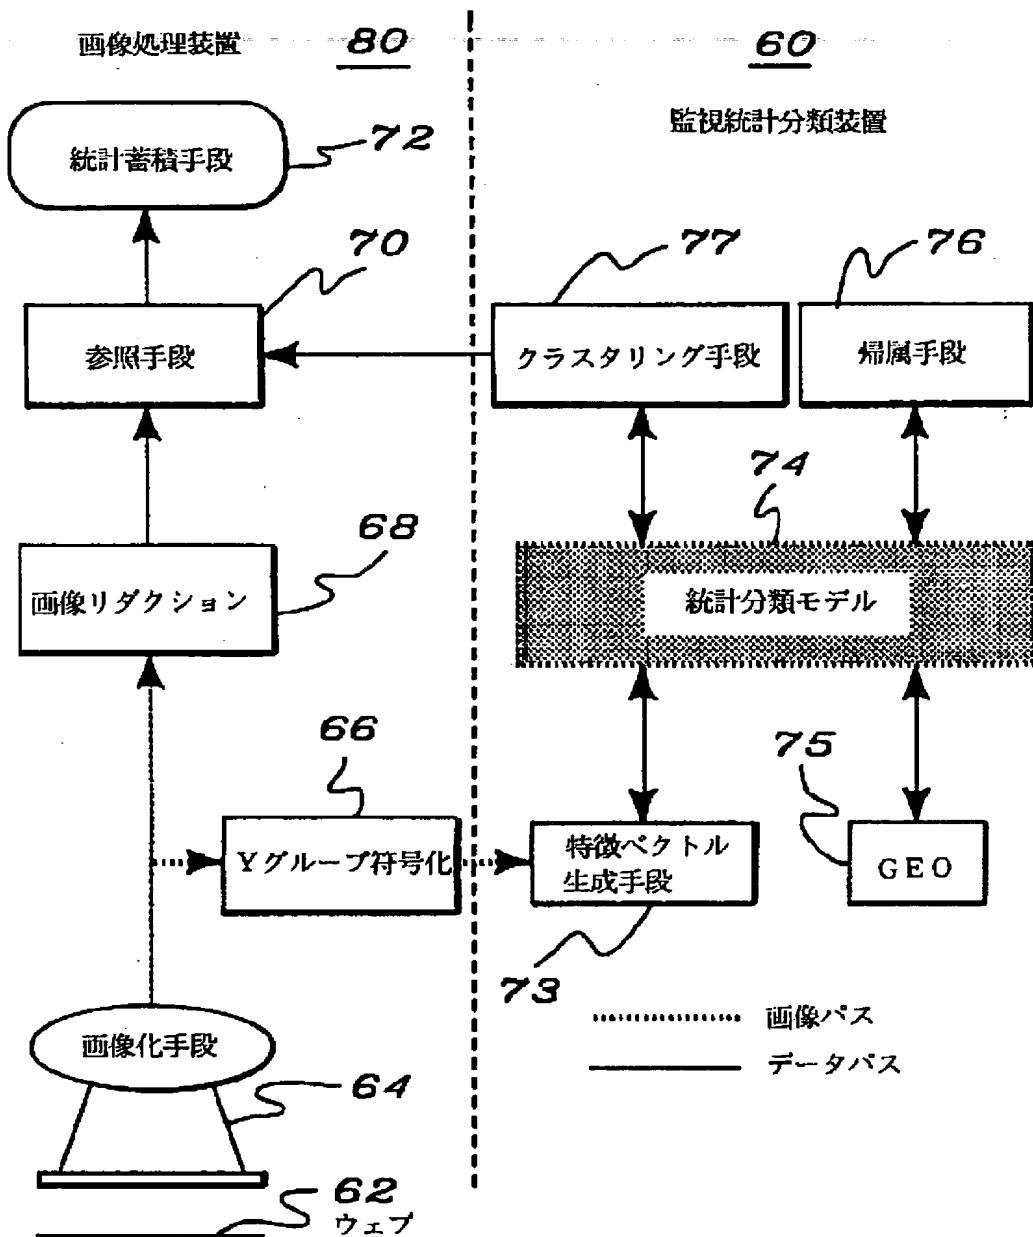
【図3】



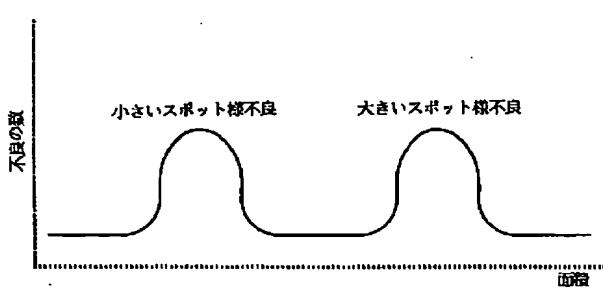
【図6】



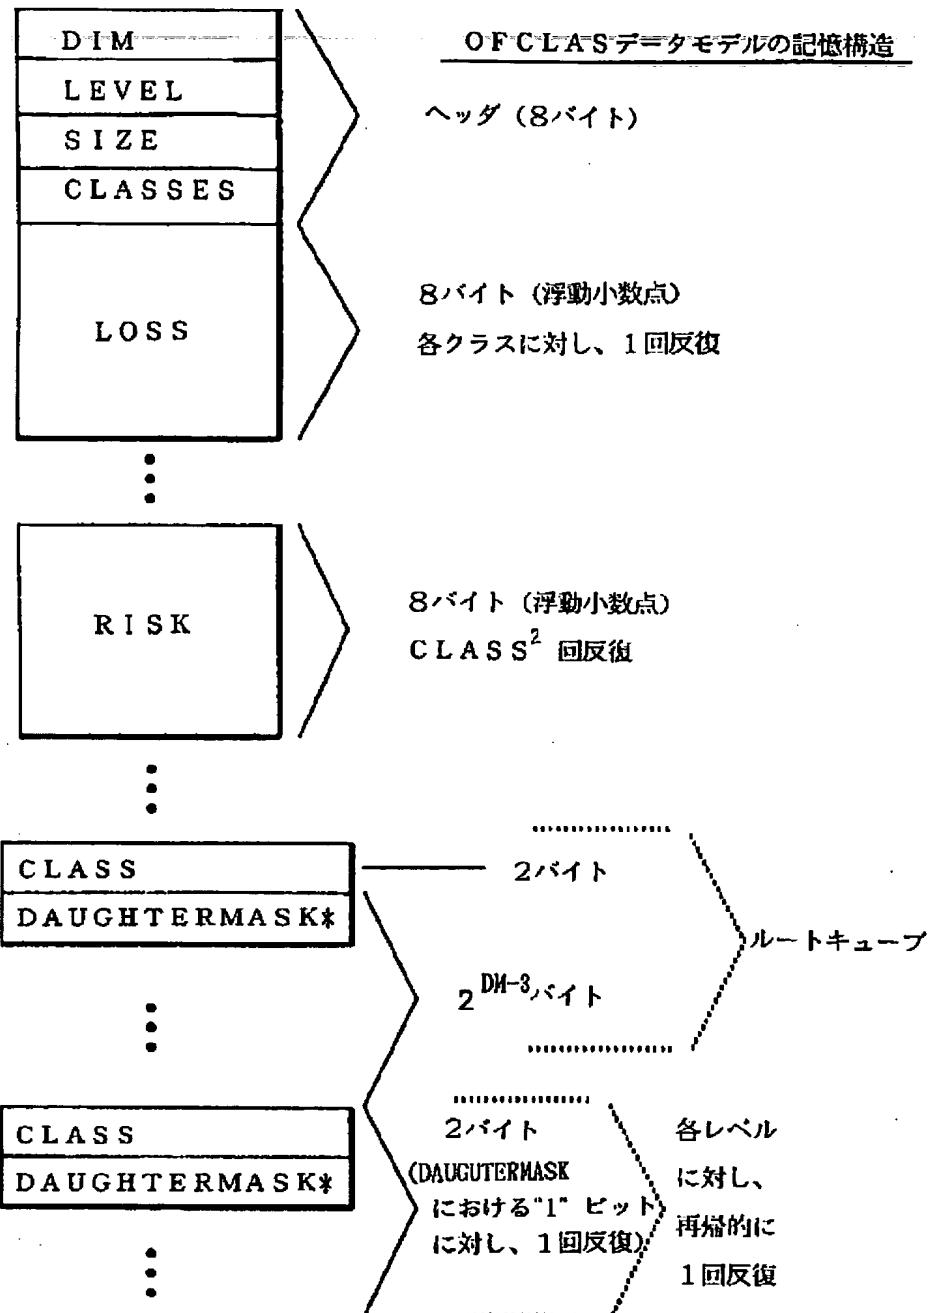
【図1】



【図7】

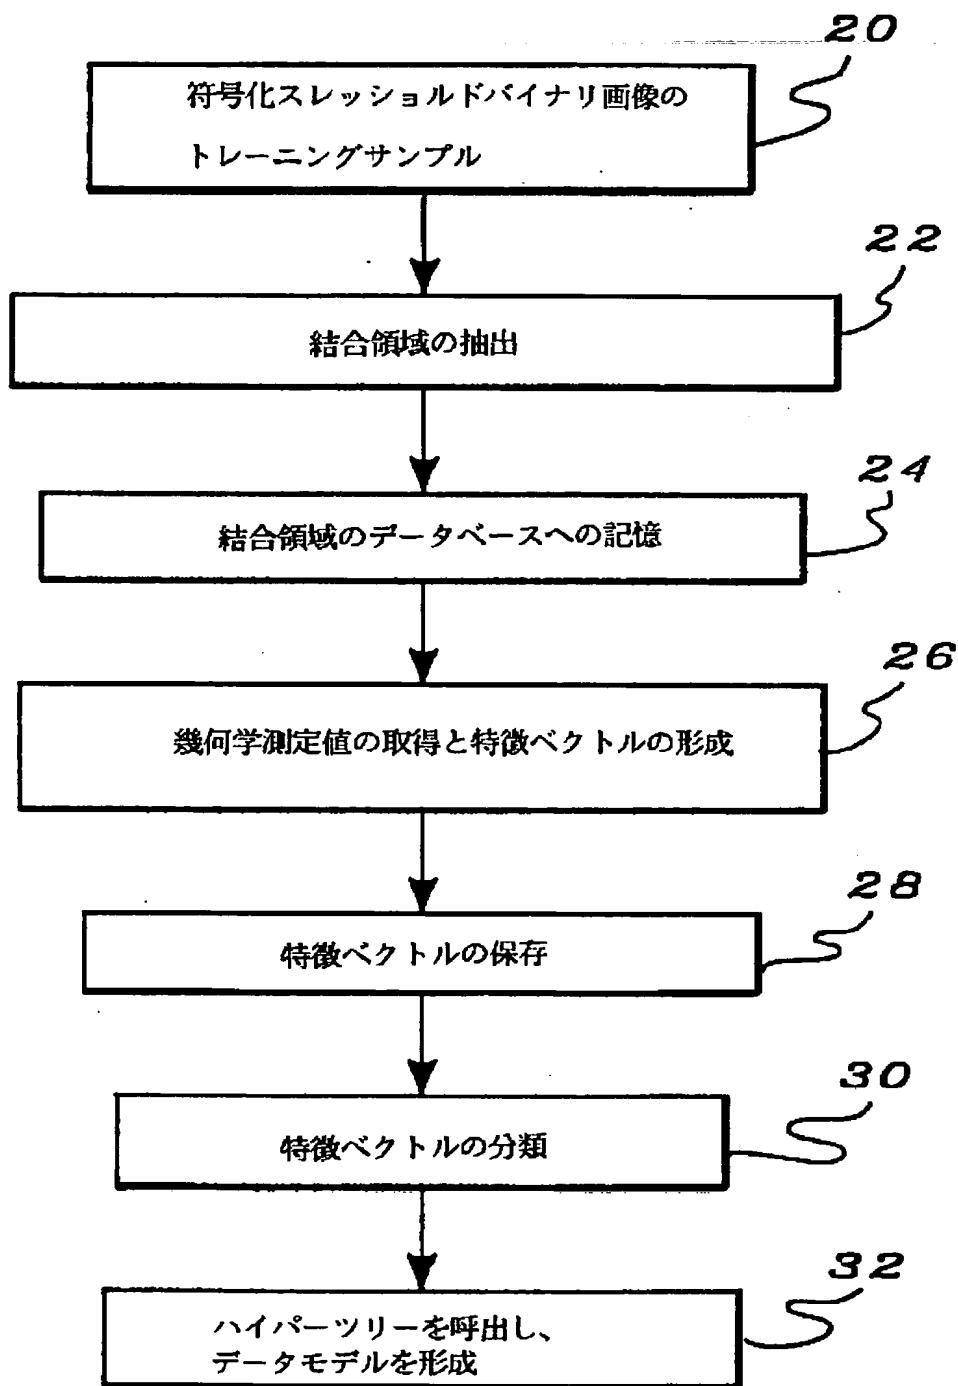


【図2】

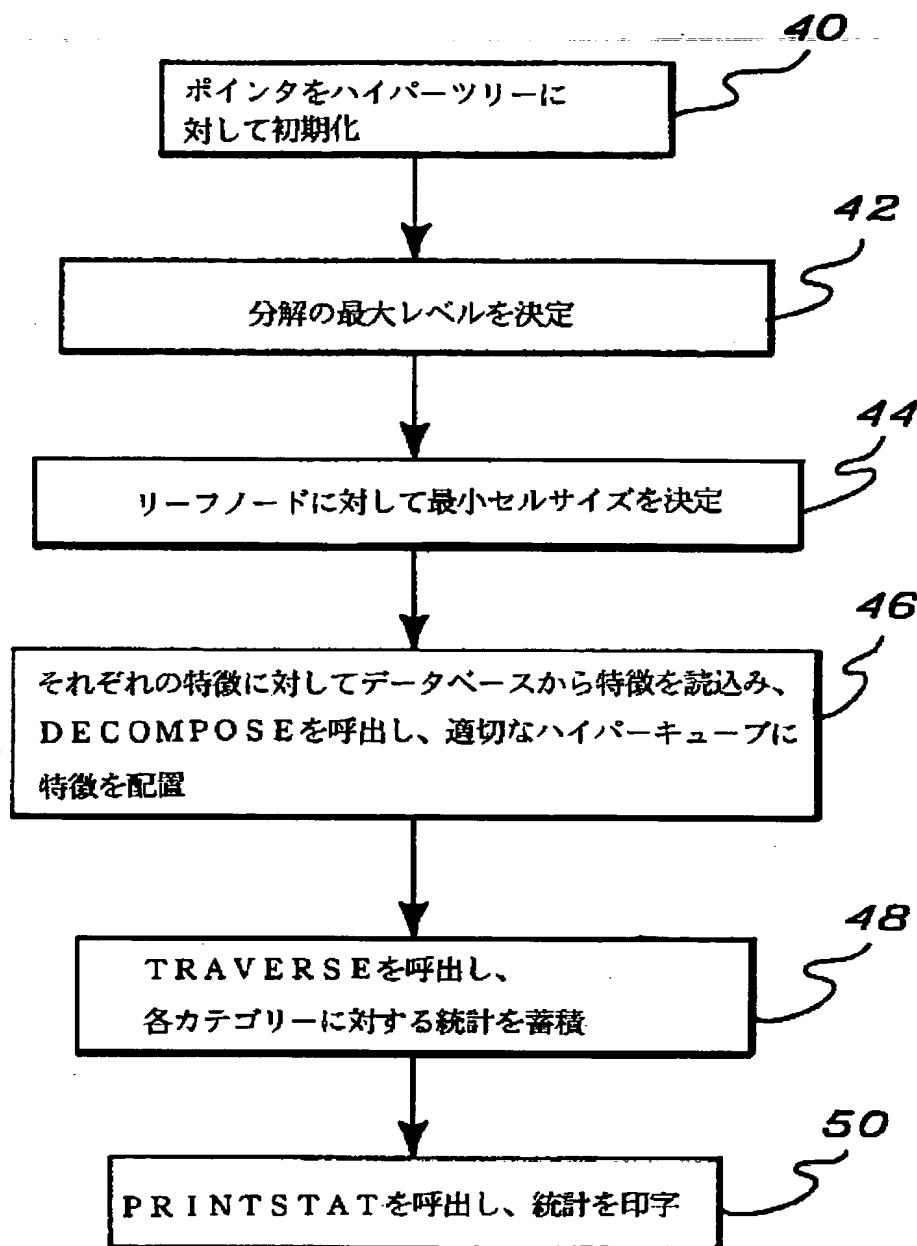


* CLASSにおけるMSBが設定された場合にのみ出現

【図4】



【図5】



整理番号 F 0 8 5 9 7 A 1

発送番号 1 7 9 3 6 1
発送日 平成 15 年 5 月 27 日 1 / 3

拒絶理由通知書

特許出願の番号	特願 2 0 0 1 - 0 8 1 5 3 2
起案日	平成 15 年 5 月 23 日
特許庁審査官	岩間 直純 9 2 8 7 5 L 0 0
特許出願人代理人	志賀 正武 (外 1 名) 様
適用条文	第 29 条柱書、第 29 条第 2 項

この出願は、次の理由によって拒絶をすべきものである。これについて意見があれば、この通知書の発送の日から 3 か月以内に意見書を提出して下さい。

理 由

A.

この出願の下記の請求項に係る発明は、その出願前日本国内又は外国において頒布された下記の刊行物に記載された発明又は電気通信回線を通じて公衆に利用可能となった発明に基いて、その出願前にその発明の属する技術の分野における通常の知識を有する者が容易に発明をすることができたものであるから、特許法第 29 条第 2 項の規定により特許を受けることができない。

記 (引用文献等については引用文献等一覧参照)

請求項 1 - 1 1 に対して

引用文献 1

引用文献 1 には、監視統計パターン認識を用いる特徴分類に係るものであって、段落【0022】 - 【0025】に記載されたような、ハイパーツリーアルゴリズムで特徴ベクトルのクラスタを生成すること、及び当該ハイパーツリーを用いたパターン認識が記載されている。

引用文献 1 に記載のハイパーツリーアルゴリズムはハイパーキューブに点が到達する毎に逐次的にハイパーキューブを分割するものであるが、これをオフライン処理として「(a) 特徴ベクトルが集中したセルが存在しているかを判別する段階と、(b) 前記(a) 段階において特徴ベクトルが集中したセルが存在すると判別されれば、特徴ベクトルのデータ空間を階層的にインデクシングする段階」と変更することは、当業者が容易に想到し得たものと認められる。

よって、請求項 1 - 1 1 に係る発明は引用文献 1 に基づき当業者が容易に想到し得たものと認められる。

引用文献等一覧

1. 特開平06-036038号公報

B.

この出願の下記の請求項に係る発明は、下記の点で特許法第29条第1項柱書に規定する要件を満たしていないので、特許を受けることができない。

記

請求項1-6, 10, 11に対して

請求項1-6に係るものは、「特徴ベクトルデータのデータ空間のインデクシング方法」という数学的アルゴリズムに係るものであり、「自然法則を利用した技術的思想の創作」とは認められない。

請求項10, 11に係るものも、同様に「特徴ベクトルがインデクシングされている特徴ベクトルのデータ空間内にて類似度を検索する方法」という数学的アルゴリズムに係るものであり、「自然法則を利用した技術的思想の創作」とは認められない。

請求項7-9に対して

請求項7-9に係るものは、「特徴ベクトルのデータ空間をインデクシングする方法を行うプログラムコードを保存するコンピュータ読み取りの可能な記録媒体」であるが、当該プログラムを構成する各段階において、何らハードウェア資源について記載されておらず、「ソフトウェアによる情報処理が、ハードウェア資源を用いて具体的に実現されている」ものとは言えない。よって、請求項7-9に係るものは、「自然法則を利用した技術的思想の創作」とは認められない。

拒絶の理由が新たに発見された場合には拒絶の理由が通知される。

先行技術文献調査結果の記録

・調査した分野 I P C 第7版 G 0 6 F 1 9 / 0 0

・先行技術文献

1. 特開平11-242674号公報
2. 特開2000-222439号公報

この先行技術文献調査結果の記録は、拒絶理由を構成するものではない。

この拒絶理由通知の内容に関するお問い合わせ、または面接のご希望がござい

発送番号 179361
発送日 平成15年 5月27日 3 / 3

ましたら下記までご連絡下さい。

特許審査第四部電子商取引 岩間直純

TEL. 03 (3581) 1101 内線3562

FAX. 03 (3501) 0737